

# Localização em Ambientes *Indoor* a partir da Distorção de um Padrão de Fontes Luminosas

Letícia A. Dominguez e Lisandro Lovisolo

**Resumo**— Este trabalho apresenta um sistema de localização baseado em imagens de fontes luminosas compostas por diodos emissores de luz (LEDs - *light-emitting diode*). As distorções do padrão de LEDs capturado dependem da posição do sensor de imagem. Processando a imagem capturada, é possível estimar a localização do sensor com baixa complexidade. Investigamos o desempenho de tal abordagem usando *fingerprinting* com diferentes funções de medida de similaridade e redes neurais artificiais para estimar a posição do sensor. Os resultados indicam que com o uso de redes neurais artificiais, boas estimativas de posição são viáveis.

**Palavras-Chave**— Posicionamento *indoor*, *Fingerprinting*.

**Abstract**— This work presents a localization system using images of light sources composed of light emitting diodes. The distortions of the captured LED pattern depend on the position of the image sensor. By processing the captured image, we can estimate the location of the sensor with low complexity. We investigate this system's performance using *fingerprinting* with different similarity measurement functions or artificial neural networks to obtain the position estimate. The results point that using artificial neural networks reasonably accurate position estimates are viable.

**Keywords**— *Indoor Positioning*, *Fingerprinting*.

## I. INTRODUÇÃO

Sistemas de localização são cada vez mais utilizados e estão cada vez mais inseridos no cotidiano, tanto para fins pessoais quanto profissionais e corporativos. Sistemas de posicionamento global via satélite (GNSS - *Global Navigation Satellite System* [1]) têm sido amplamente usados para referenciar dispositivos no espaço que podem ser carregados por indivíduos, carros, navios, entre outros. Diversas aplicações têm surgido que demandam a localização de objetos em locais fechados como industriais, centros comerciais e/ou residenciais, lojas, dentre outros. Contudo, a disponibilidade e o desempenho de GNSSs em ambientes *indoor* são limitados, pois o sinal do satélite é refletido e/ou atenuado por estruturas prediais e portanto a detecção do sinal é dificultada e a localização é pouco acurada em comparação à obtida em ambientes *outdoor*.

Conseqüentemente, técnicas de localização alternativas têm sido propostas para ambientes *indoor*, muitas delas empregam, por exemplo, sinais provenientes de roteadores WiFi [1], mas sua aplicabilidade depende de diversos fatores externos que podem comprometer seu desempenho, incluindo a quantidade de pessoas presente no local [1]. A importância de prover ferramentas de estimativas de posição em ambientes *indoor* pode ser depreendida da incorporação de recursos específicos

para posicionamento na camada MAC e PHY do WiFi no IEEE 802.11az. O objetivo é implementar sistemas de posicionamento *indoor* (IPS - *Indoor Positioning System*) de alta disponibilidade e baixo custo.

Uma alternativa para a implementação de IPSs é usar fontes luminosas. Elas podem ser empregadas como pontos de referências para obter uma localização grosseira, a partir da qual a posição do dispositivo é refinada em [2]. Em [3], a localização é obtida a partir de mudanças na resposta ao impulso do canal óptico. Já em [4], usam-se as referências de posição recebidas de transmissores ópticos e as perdas de percurso do canal óptico com uma rede neural artificial para obter a posição do receptor via trilateração. Ainda usando a informação de potência luminosa, em [5], constrói-se um banco de dados para obtenção da estimativa de posição usando um método de correlação de assinaturas na região de operação do sistema de posicionamento. A combinação de características do enlace de comunicação óptico sem fio (OWC - *Optical Wireless Communications*) [6], [7] com informações de outros dispositivos como acelerômetros e receptores específicos é empregada para localização em [8], [9], [10]. O reconhecimento de imagens e etiquetas referenciais é empregado para estimar a posição de sensores de imagem em [11].

Neste trabalho, propomos e estudamos um IPS a partir de fontes luminosas específicas e do processamento de imagem capturada. Empregam-se as distâncias entre as projeções de um padrão conhecido de LEDs no sensor de imagem para estimar a posição do sensor. Aproveitando-se do barateamento de dispositivos de imageamento e da proposição de sistemas de comunicação por luz visível, tal estratégia prescinde de medidas específicas de intensidade da luz recebida e de estratégias de trilateração, resultando num IPS de baixa complexidade que utiliza apenas uma única imagem. O sistema proposto pode ser empregado sob diferentes níveis de exposição luminosa e sua aplicação para robôs de serviço em ambiente internos e dispositivos IoT (*Internet of Things*) é simples.

Para estimar a posição do sensor investigamos a correlação entre padrões de distâncias entre LEDs armazenados e aquele medido no local de interesse conhecido como *fingerprinting* ou *scene analysis*. Para aumentar a acurácia dessa abordagem, empregamos a média ponderada de posições candidatas com pesos obtidos por IDW (*Inverse Direct Weighting*). Outra abordagem testada é o emprego de uma rede neural artificial (RNA) para estimar a posição do sensor de imagem diretamente a partir das distâncias entre LEDs (padrão capturado), invertendo o mapeamento entre posição e padrão capturado.

O restante deste artigo está organizado da seguinte forma. A

Seção II apresenta a concepção e o arranjo físico do sistema de localização *indoor* proposto. A Seção III aborda os métodos aplicados para obter a estimativa de posição. Os resultados de simulações e suas análises são apresentadas na Seção IV. Apresentamos nossas conclusões e pretensões para trabalhos futuros na Seção V.

## II. SISTEMA DE LOCALIZAÇÃO INDOOR PROPOSTO

Imagina-se um arranjo de LEDs e uma câmera para a captação das imagens, como receptor sistema de localização. Tal arranjo é afixado no ambiente - no caso, no teto. O padrão é registrado pela câmera, mas mudará em função das posições relativas entre o arranjo de LEDs e a câmera. Isso é ilustrado na Figura 1.

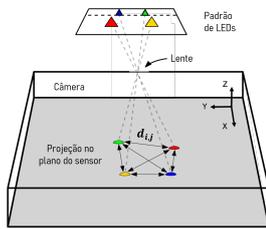


Fig. 1. Arranjo de LEDs para o IPS proposto (composto por quatro LEDs de cores distintas).

Portanto, se o objeto alvo (a ser localizado) embarca uma câmera, podemos estimar a sua posição relativa ao padrão por meio da projeção do arranjo na imagem. Com este modelo podemos localizar desde um *smartphone* no interior de uma sala até um carrinho de mercadorias num supermercado ou de insumos num galpão de fábrica.

Nossa abordagem considera que, em cada posição de captura, tem-se uma projeção diferente do arranjo da qual podemos obter as distâncias entre os pontos (LEDs) projetados na imagem capturada. Essas distâncias variam com a posição e são dadas por (ignorando distorções da lente e seu desalinhamento perpendicular com o eixo  $z$ )

$$d_{i,j}^2 = f^2 \left[ \frac{(m_x^2)(x'_i - x'_c)^2 + (m_y^2)(y'_i - y'_c)^2}{(z'_i - z'_c)^2} + \frac{(m_x^2)(x'_j - x'_c)^2 + (m_y^2)(y'_j - y'_c)^2}{(z'_j - z'_c)^2} - 2 \frac{(m_x^2)(x'_i - x'_c)(x'_j - x'_c) + (m_y^2)(y'_i - y'_c)(y'_j - y'_c)}{(z'_i - z'_c)(z'_j - z'_c)} \right], \quad (1)$$

onde  $i$  e  $j$  indicam dois LEDs distintos,  $(x'_i, y'_i, z'_i)$  é a posição do  $i$ -ésimo LED,  $(x'_c, y'_c, z'_c)$  a posição da câmera, ambos num mesmo espaço de coordenadas,  $f$  é a distância focal do sensor e  $m_x$  e  $m_y$  a quantidade de pixels por unidade de comprimento nas direções  $x$  e  $y$  no sensor [12],[13].

A princípio, as distâncias entre os LEDs na imagem capturada permitem saber a localização de captura. Porém, para estabelecer um mapeamento entre as distâncias entre os LEDs na imagem obtida e a posição, os LEDs deverão ter alturas diferentes. Caso contrário, haverá uma ambiguidade na estimativa da posição (devida a projeção) impossibilitando estimar

a posição. A proposta requer ainda linha de visada (*Line of Sight* – LoS) entre o padrão e o dispositivo de imageamento. Em ambientes com oclusão ou em grandes áreas, isso pode ser garantido dispondo mais padrões referenciais. A seguir, investigamos abordagens para inverter o mapeamento de um conjunto de distâncias  $d_{i,j}$  – equação (1) – para posições relativas entre o sensor e o arranjo de LEDs.



Fig. 2. Diagrama entrada-saída do estimador de posição.

## III. MÉTODOS

Para estimar a posição relativa do dispositivo em função das distâncias entre as projeções na imagem podemos empregar o conjunto de distâncias  $\{d_{i,j}\}_{i,j=1\dots N, i \neq j}$  composto de  $N(N-1)/2$  elementos. Vemos que a equação (1) não é linear dificultando a inversão. Assim, para estimar a posição, usaremos técnicas baseadas em conhecimento prévio. Suporemos a possibilidade de capturar conjuntos de distâncias em diferentes posições relativas entre o arranjo e sensor de imagens. Essas informações são coletadas em diferentes posições e armazenadas num banco de dados. Esse banco de dados é empregado como “referência” ou para “treinamento” do algoritmo de localização. Tais abordagens têm a vantagem de serem agnósticas em relação à configuração do arranjo de LEDs e dos parâmetros intrínsecos e extrínsecos da câmera.

### A. Fingerprinting ou Scene Analysis

O conjunto de distâncias coletadas é o CDB (*Correlation Database*) [1]. O CDB é o conjunto de “referência”,  $\mathbf{d}_i^{(r)}$ , sendo  $i$  o índice para a referência. A um conjunto de distâncias para a qual queremos estimar a posição de coleta chamamos de “alvo”  $\mathbf{d}^{(a)}$ . Para estimar essa posição, podemos procurar no CDB pela referência mais similar à alvo e a posição é retornada como a posição dessa referência

$$(\hat{x}, \hat{y}, \hat{z}) = (x_i, y_i, z_i) \text{ tal que } i = \arg \min_{i \in \text{CDB}} d(\mathbf{d}_i^{(r)}, \mathbf{d}^{(a)}), \quad (2)$$

na qual,  $d(\mathbf{v}, \mathbf{u})$  é uma medida de distância entre os dois vetores – quanto menor for a distância, maior é a similaridade.

Além dessa abordagem, usamos também a correlação entre os padrões. Neste caso procuramos pelo padrão do CDB com maior correlação com o alvo para estimar a posição. Neste caso, os conjuntos de distâncias são processados para terem média zero e norma unitária e buscamos por

$$(\hat{x}, \hat{y}, \hat{z}) = (x_i, y_i, z_i) \text{ tal que } i = \arg \max_{i \in \text{CDB}} \langle \mathbf{d}_i^{(r)}, \mathbf{d}^{(a)} \rangle, \quad (3)$$

na qual,  $\langle \mathbf{v}, \mathbf{u} \rangle$  é o produto interno entre  $\mathbf{v}$  e  $\mathbf{u}$ .

Usando essas abordagens, o erro de localização (a diferença entre a posição de coleta do padrão alvo e o de referência

estimado como posição alvo) irá depender da densidade de pontos de referência. Se os pontos de referência estão dispostos a intervalos regulares nas coordenadas  $x$ ,  $y$  e  $z$ , quanto mais deles houver por unidade de volume, a princípio menor será o erro da estimativa de localização.

Para reduzir o erro incorrido na posição estimada podemos ponderar as posições associadas aos  $M$  padrões de referência mais similares ao alvo via

$$\hat{\mathbf{p}} = \frac{\sum_{k=1}^M w_k \mathbf{p}_{i_k}}{\sum_{k=1}^M w_k}, \quad (4)$$

sendo  $\mathbf{p}_{i_k}$  a  $i$ -ésima posição  $(x, y, z)$  considerada na média e  $n > 0$ . Por exemplo, para um CDB com espaçamentos regulares, fazemos  $M = 8$  pontos, visto que esses pontos geram um reticulado de cubos, que têm 8 vértices. Para determinar os pesos  $w_k$  na equação (4) usamos a IDW (*inverse distance weighting*) [14], assim  $w_k = \frac{1}{d(\mathbf{v}, \mathbf{u})^n}$  ( $n > 0$ ) quando empregamos a diferença entre os conjuntos de distâncias como critério de casamento de padrões. Similarmente, quando empregamos a correlação, fazemos  $w_k = \langle \mathbf{v}, \mathbf{u} \rangle$ .

### B. Redes Neurais

Outra alternativa é empregar um algoritmo de aprendizado supervisionado para obter um estimador para a posição alvo [15]. Fazemos isso com os conjuntos de distâncias de referência como entradas e as posições associadas as saídas no treinamento de rede neural [16]. Assim, obtém-se um regressor ou estimador para a posição de um conjunto de distâncias a ele apresentado na entrada.

### C. Avaliação de Desempenho de Métodos de Localização

O intuito de um sistema de localização ou posição é estimar a posição do dispositivo sem medir diretamente distâncias. Para avaliar o sistema usamos o erro entre a posição real do dispositivo  $\tilde{\mathbf{p}}$  e a estimada pelo sistema de estimativa de localização  $\hat{\mathbf{p}}$

$$\mathbf{e} = \tilde{\mathbf{p}} - \hat{\mathbf{p}} = (\tilde{x}, \tilde{y}, \tilde{z}) - (\hat{x}, \hat{y}, \hat{z}). \quad (5)$$

A partir desse erro pontual, podemos calcular seu módulo,  $e = |\mathbf{e}|$  e, conseqüentemente, a acurácia e a precisão do método. Neste trabalho, de forma a avaliar as diferentes técnicas de estimativa da posição discutidas usaremos a função de distribuição cumulativa (CDF – *cummulative distribution function*) do erro de localização  $F_E(e') = \text{probabilidade}(e \leq e')$ . Para um dado valor  $e'$ ,  $F_E(e')$  fornece a fração dos erros de localização que são inferiores a  $e'$ . Avaliamos os diferentes métodos de posicionamento a partir do padrão capturado usando a CDF da estimativa do erro de localização obtida por eles. Porém, antes de apresentar os resultados, devemos tecer alguns comentários sobre os métodos empregados.

### D. Sobre as Abordagens

Métodos *Fingerprinting* têm desempenhos dependentes da densidade do CDB [1]; quanto mais pontos há para comparação e mais distribuídos eles forem na região melhor

será a estimativa de posição. Para tal, é necessário reduzir o passo de discretização espacial na região onde se pretende usar o sistema; a primeira dificuldade inerente a esse aumento da densidade está na construção do CDB, e a segunda é que quanto maior ele for, maior o tempo de resposta pois há uma elevação na quantidade de operações necessárias para obter o padrão de referência mais similar ao padrão alvo.

O uso do IDW, permite ao sistema entregar como estimativa uma posição que não constitui o banco de dados; isto é, que não esteja no CDB. Com isso, podemos a princípio obter estimativas melhores da posição correspondente ao padrão alvo, reduzindo o tempo de resposta. Entende-se, portanto, que é possível empregar um CDB menos denso e prover uma acurácia similar à obtida usando um CDB mais denso na região onde se pretende estimar a posição de um dispositivo.

Espera-se que a Rede Neural, após treinada, seja capaz de generalizar, isto é, prover estimativas de posição a partir de um padrão que não foi apresentado ao sistema durante o treinamento. Usando os conjuntos de medidas de referência para obter estimativas de posição e ajustar os pesos nas sinapses, após várias épocas, podemos chegar à convergência, e sem gerar sobre treinamento. Detalhes sobre a topologia e o treinamento da RNA são apresentados na Subseção IV-A.6. O tempo de aprendizado (treinamento) da RNA é maior que o dos métodos fingerprinting acima discutidos, porém, uma vez treinada, ela consegue entregar uma estimativa da posição num tempo de resposta menor que os outros métodos.

O desempenho de quaisquer dos métodos sofre influência da cardinalidade (quantidade de elementos) do conjunto de referência. Nos métodos fingerprinting, reduzir a cardinalidade do conjunto reduz também o tempo de resposta, no método usando RNA ela reduz o tempo de treinamento, sem impactar o tempo de resposta. Porém, essas reduções de tempo (complexidade) devem ser tais que não piorem substancialmente o desempenho dos métodos. Conseqüentemente, um dos balizadores do processo de avaliação das diferentes metodologias a seguir é tal compromisso.

## IV. SIMULAÇÕES E RESULTADOS

Testou-se o sistema de posicionamento a partir do padrão de LEDs variando diferentes aspectos sistêmicos. Todas as simulações foram executadas com a ferramenta MatLab.

### A. Configurações dos Testes

1) *Área Alvo e Configuração do Padrão de LEDs*: a área alvo tem 4.0 m  $\times$  4.0 m e a altura entre o padrão de LEDs e o piso é de de 3.0 m. O padrão de LEDs é sempre utilizado como a referência fixa do sistema; os LEDs estão dispostos nos vértices de um quadrado de lado igual a 15 cm com alturas  $z_{\text{LEDs}} = \{0, 2.5, 5, 7.5\}$  cm, relativamente ao teto.

2) *Construção dos CDBs: Referência e Alvo*: de forma a aferir a capacidade dos métodos em obter estimativas de posição adequadas, empregamos dois CDBs distintos. O CDB de referência contém as referências empregadas nos métodos fingerprinting e no treinamento das RNAs, enquanto o de teste contém os alvos que usamos para testar o desempenho dos métodos que provêm as estimativas de posições. Ambos são

obtidos usando reticulados cúbicos com 10 cm de lado; porém, um está descolado do outro de 5 cm em cada um dos 3 eixos. Cada CDB contém aproximadamente  $40 \times 40 \times 30 = 48 \cdot 10^3$  elementos.

3) *Características das Câmeras*: na simulação, 3 modelos distintos de câmeras reais foram utilizados a fim de observar as variações de desempenho em função das características de cada câmera. As câmeras 1 (MSC-420 HS), 2 (GS-NPR640C series) e 3 (HM-65DN), são câmeras pinhole. Os sensores de todas as câmeras ocupam mesma área de  $3.6\text{mm} \times 4.8\text{mm}$ , porém as quantidades de pixels e as alturas de seus focos são apresentadas na Tabela I.

TABELA I  
PARÂMETROS INTRÍNSECOS DAS CÂMERAS.

Cam.	Mx	My	Foco (mm)
1	510	492	2.8
2	1280	720	3.7
3	768	494	5

4) *Complexidade e Uniformidade do CDB  $\times$  Desempenho*: os desempenhos dos diferentes métodos são avaliados usando a CDF do erro de localização (Subseção III-C). Para avaliar as possíveis alterações de desempenho de cada método quando a quantidade de dados de referência é alterada, usamos versões randomicamente sub-amostradas do conjunto de dados de referência. Para isso, usamos o banco de medidas de referência completo e 25% de seus registros (testou-se também 50% e 75%, entretanto, como a variação é ínfima, não os apresentamos). A escolha randômica dos pontos de referência que compõem o CDB reduzido acarreta uma subamostragem não-uniforme do mesmo, resultando num CDB não-uniforme (no qual a distância entre entrada vizinhas não estão regularmente espaçadas, mais plausível em sistemas reais).

5) *Configuração do Método de Fingerprinting*: conforme anteriormente descrito, aplicamos o método de fingerprinting avaliando a similaridade, tanto por diferença entre as distâncias nas imagens quanto por produto interno entre as mesmas, com diferentes quantidades de elementos do CDB de referência.

6) *Configuração da RNA*: a RNA empregada é uma MLP (*multi-layer Perceptron*) [16] com 6 entradas na primeira camada, 3 saídas e 6 camadas ocultas compostas por [6 9 12 15 9 6] neurônios, na respectiva ordem. Elas são treinadas usando o algoritmo *Levenberg-Marquardt backpropagation* [17] de segunda ordem; a função de ativação empregada é a sigmoide. A rede é treinada com o CDB de referência; o conjunto de Treino é composto por 55% das entradas, o de Teste 25% e o de Validação 20% dos elementos do CDB de referência, aleatoriamente selecionadas.

## B. Resultados

Para uma posição alvo selecionada randomicamente, estima-se a posição e obtém-se o erro. Avaliamos esse erro para 11.408 pontos do CDB alvo para cada um dos diferentes métodos, obtendo assim as CDFs dos erros de posição. A Figura 3 apresenta as CDFs dos erros de localização quando empregamos a câmera 1 para os cinco métodos discutidos. O gráfico superior nessa figura apresenta os resultados quando

o CDB de referência completo é empregado nas variantes do fingerprinting e no treinamento das RNAs, por isso, o título “100% do CDB”. O gráfico inferior, apresenta os resultados quando apenas 25% das entradas do CDB de referência são empregadas, aleatoriamente escolhidas. A Figura 4 apresenta os resultados obtidos usando a mesma metodologia para a câmera 2 e a Figura 5 para a câmera 3. Nessas avaliações, emprega-se a validação cruzada via *k-fold*, com  $k=10$ . E, os resultados apresentados são as médias dessas 10 rodadas.

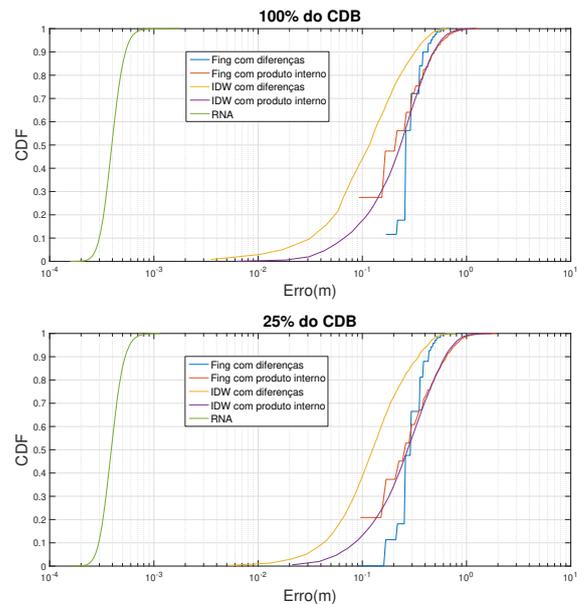


Fig. 3. CDF do erro dos sistema de posicionamento usando a câmera 1 e conjuntos de referências alvos compostos por frações do CDB. O gráfico superior considera o uso completo do CDB e o inferior 25% do mesmo.

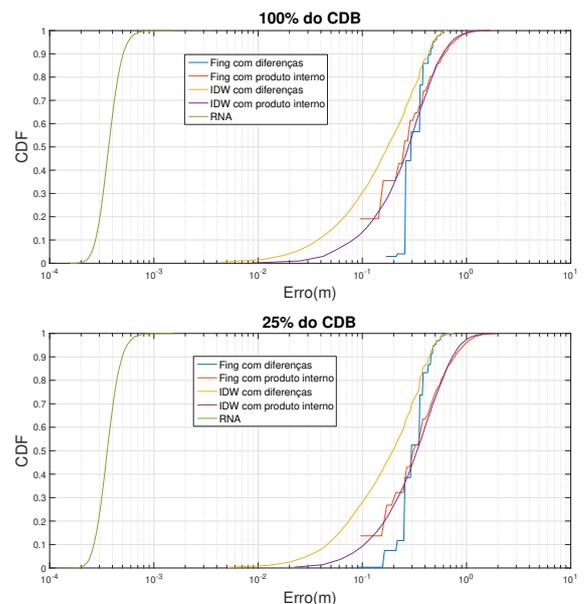


Fig. 4. CDF do erro dos sistema de posicionamento usando a câmera 2 e conjuntos de referências alvos compostos por frações do CDB. O gráfico superior considera o uso completo do CDB e o inferior 25% do mesmo.

Primeiramente, destacamos que a aplicação do IDW reduz o erro da posição estimada. Porém, essa melhora é maior

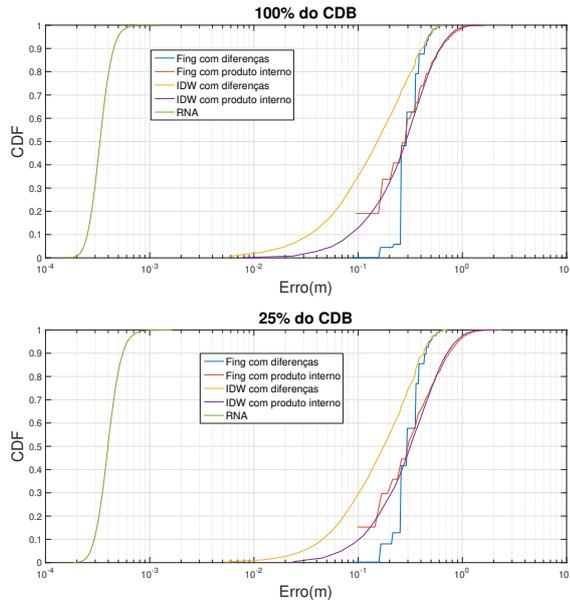


Fig. 5. CDF do erro dos sistemas de posicionamento usando a câmera 1 e conjuntos de referências alvo compostos por frações do CDB. O gráfico superior considera o uso completo do CDB e o inferior 25% do mesmo.

quando usamos as diferenças entre os padrões de distâncias do que quando usamos o produto interno como medidas de similaridades. A ligeira queda de desempenho relativo, quando se emprega o produto interno, se deve à normalização dos vetores (padrões). A normalização que faz com que padrões de distâncias entre LEDs correspondentes a posições distintas se pareçam, dificultando a estimação correta da posição alvo. Se por um lado, para que isso ocorra, os padrões já devem ter direções similares antes da normalização, vemos que eles têm amplitudes diferentes conforme mostram os erros de posição consistentemente menores obtidos empregando a diferença.

Complementarmente, vemos que o IDW (que produz uma estimativa de posição usando a média de posições de referência) é capaz de melhorar o desempenho do sistema razoavelmente quando a diferença entre padrões é empregada, mas não quando a correlação o é. Tal fato corrobora que para os padrões de distâncias entre as projeções dos LEDs a correlação não é uma boa medida de similaridade, i.e., capaz de discernir entre padrões correspondentes a posições espacialmente afastadas.

O uso de RNAs fornece em todos os casos (câmeras e frações do CDB) resultados consistentemente melhores do que os anteriormente discutidos. Utilizando RNAs, atinge-se o percentil 100% num erro de posição que é três ordens de grandeza abaixo do que aqueles obtidos com IDW.

A redução da cardinalidade do CDB provoca uma redução de desempenho, porém pequena. Os métodos fingerprinting pioram consideravelmente. Por outro lado, a RNA é bastante menos sensível a essa redução, e o erro parece continuar aceitável para uso na maioria das aplicações vislumbradas.

## V. CONCLUSÕES

Este trabalho propôs um sistema alternativo de posicionamento interno, capaz de ser facilmente reproduzido e

aplicado por meio de um padrão luminoso. O método não emprega angulação nem medidas de intensidade, o que lhe permite operar em diferentes cenários. O sistema baseia-se em um processamento de imagens para medir a distância entre as projeções de pontos num sensor de imagens e a estimativa da posição de captura da imagem a partir dessas distâncias. Os resultados apresentados indicam a viabilidade da proposição e que o método de obtenção da estimativa de posição baseado em uma RNA MLP é o mais apropriado apresentando desempenho satisfatório para a aplicação *indoor* mesmo quando a quantidade de dados usados no treinamento é bastante reduzida. Em trabalhos futuros, pretende-se estudar sensibilidade do sistema aos parâmetros do padrão luminoso e a possibilidade da aplicação do sistema utilizando LEDs brancos com a luz modulada de forma a identificar cada um dos LEDs no sensor de imagem.

## REFERÊNCIAS

- [1] R. S. Campos and L. Lovisolo, *RF positioning: fundamentals, applications, and tools*. Artech House, 2015.
- [2] V. Landa, B. Ben-Moshe, S. Hacoheh, and N. Shvalb, "Goin—an accurate 3d indoor navigation framework based on light landmarks," *Navigation*, vol. 66, no. 3, pp. 633–642, 2019.
- [3] K. Majeed and S. Hranilovic, "Performance bounds on passive indoor positioning using visible light," *Journal of Lightwave Technology*, vol. 38, no. 8, pp. 2190–2200, 2020.
- [4] W. Sayed, T. Ismail, and K. Elsayed, "A neural network-based vlc indoor positioning system for moving users," in *2019 International Conference on Smart Applications, Communications and Networking (SmartNets)*, pp. 1–6, IEEE, 2019.
- [5] C. Xiaohong, Q. Chen, and W. Wei, "An indoor positioning scheme for visible light using fingerprint database with multiparameters," *ZTE Communications*, vol. 15, no. 1, pp. 43–48, 2019.
- [6] I. Takai, S. Ito, K. Yasutomi, K. Kagawa, M. Andoh, and S. Kawahito, "Led and cmos image sensor based optical wireless communication system for automotive applications," *IEEE Photonics Journal*, vol. 5, no. 5, pp. 6801418–6801418, 2013.
- [7] M. S. Hossen, Y. Park, and K.-D. Kim, "Performance improvement of indoor positioning using light-emitting diodes and an image sensor for light-emitting diode communication," *Optical Engineering*, vol. 54, no. 4, pp. 1–11, 2015.
- [8] P. Huynh and M. Yoo, "Vlc-based positioning system for an indoor environment using an image sensor and an accelerometer sensor," *Sensors*, vol. 16, no. 6, p. 783, 2016.
- [9] S. Juneja and S. Vashisth, "Indoor positioning system using visible light communication," in *2017 International Conference on Computing and Communication Technologies for Smart Nation (IC3TSN)*, pp. 79–83, IEEE, 2017.
- [10] Y.-S. Kuo, P. Pannuto, K.-J. Hsiao, and P. Dutta, "Luxapose: Indoor positioning with mobile phones and visible light," in *Proceedings of the 20th annual international conference on Mobile computing and networking*, pp. 447–458, 2014.
- [11] F. Jabbarov and J. Cho, "Image-Based Camera Localization Algorithm for Smartphone Cameras Based on Reference Objects," *Wireless Personal Communications*, 2020.
- [12] L. Coelho and J. N. Brito, *Fotogrametria Digital*. Editora da UNIVERSIDADE DO ESTADO DO RIO DE JANEIRO, 2007.
- [13] L. Lovisolo, M. P. Tcheou, and F. R. Aacute; vila, "Visible light-based communication and localization," *Handbook of Position Location: Theory, Practice, and Advances, Second Edition*, pp. 1121–1164, 2018.
- [14] D. Shepard, "A two-dimensional interpolation function for irregularly-spaced data," in *Proceedings of the 1968 23rd ACM national conference*, pp. 517–524, 1968.
- [15] D. Anderson and G. McNeill, "Artificial neural networks technology," *Kaman Sciences Corporation*, vol. 258, no. 6, pp. 1–83, 1992.
- [16] S. Haykin, *Redes neurais: princípios e prática*. Bookman Editora, 2001.
- [17] C. Lv, Y. Xing, J. Zhang, X. Na, Y. Li, T. Liu, D. Cao, and F. Wang, "Levenberg-marquardt backpropagation training of multilayer neural networks for state estimation of a safety-critical cyber-physical system," *IEEE Transactions on Industrial Informatics*, vol. 14, no. 8, pp. 3436–3446, 2018.